

ДВИГАТЕЛИ И ЭНЕРГЕТИЧЕСКИЕ УСТАНОВКИ ЛЕТАТЕЛЬНЫХ АППАРАТОВ

УДК 62.181.1

МОДЕЛЬ АНАЛИЗА И КЛАССИФИКАЦИИ ГЕОМЕТРИИ ЛОПАТОК ГАЗОТУРБИННЫХ ДВИГАТЕЛЕЙ

Печенин В.А.* , Болотов М.А.**

*Самарский государственный аэрокосмический университет
им. академика С.П. Королева (национальный исследовательский университет),
СГАУ, Московское шоссе, 34, Самара, 443086, Россия*

** e-mail: vadim.pechenin2011@yandex.ru*

*** e-mail: maikl.bol@gmail.com*

Представлена модель анализа и классификации геометрии лопаток газотурбинных двигателей (ГТД). Разработанная модель может быть использована для построения интеллектуальной системы обеспечения показателей качества авиационных двигателей. В основу математической модели положен анализ и кластеризация геометрии профиля или сложной поверхности сложных профилей и поверхностей. Приводятся результаты апробации разработанной модели на примере серии профилей корытца лопаток компрессора ГТД, полученных в результате измерения на координатно-измерительной машине DEA Global Performance 07.10.07 и искусственно смоделированных с учетом отклонений, встречающихся в практике.

Ключевые слова: анализ, преобразование Фурье, кластеризация, нейронная сеть.

Введение

Качество авиационных двигателей (удельный расход, газодинамическая устойчивость, надежность, ресурс) закладывается в процессе проектирования, отрабатывается на стадии доводки, обеспечивается в производстве и реализуется в эксплуатации. Одним из резервов повышения показателей качества авиационных двигателей является учет действительной геометрии деталей при проектировании и формирование наилучшей в текущих условиях производства геометрии изделия в процессах изготовления и сборки. Реализация названного резерва возможна с использованием модели анализа

и классификации геометрии лопаток газотурбинных двигателей.

Целью работы является разработка модели анализа и классификации геометрии лопаток газотурбинных двигателей, а также структуры интеллектуальной системы обеспечения показателей качества авиационных двигателей.

Для достижения цели необходимо решить следующие задачи:

- 1) разработать структуру интеллектуальной системы обеспечения показателей качества авиационных двигателей, тесно интегрированной в этапы жизненного цикла;

2) разработать математическую модель анализа и кластеризации сложных профилей и поверхностей;

3) разработать математическую модель формирования типовых представителей серии сложных поверхностей и анализа степени рассеивания в группах;

4) разработать перечень требований к хранению систематизированной геометрической информации и показателей качества авиационных двигателей в базе знаний.

Технологический процесс изготовления основных деталей и сборки авиационных двигателей характеризуется конечной точностью. Это приводит к отличию действительной геометрии деталей от номинальной. Геометрические параметры лопаток одной ступени отличаются не только от номинально заданной геометрии, но и друг от друга в одной ступени. Такое различие в форме сложной поверхности лопаток компрессора относительно чертежей (3D-моделей) и степень разброса параметров геометрии в ступенях влияют на газодинамическую эффективность, вибрационные характеристики и надежность компрессора. Учет различия геометрии лопаток относительно номинальной геометрии и степень их разброса в ступенях на этапе процесса проектирования позволит сформировать уточненные требования к изделию и определить пути повышения показателей качества авиационных двигателей. Формирование наилучшей в текущих условиях производства геометрии лопаток по степени отличия от CAD-модели и расхождения друг от друга для ступеней в производстве позволит повысить показатели качества. Это возможно реализовать тремя способами. В первом способе предполагается формирование сборочных комплектов лопаток для ступеней на основе системы комплектования по геометрическим особенностям сложных поверхностей отдельных лопаток. Во втором способе предполагаются интеллектуальный анализ и распознавание сложной геометрии серийно производимых лопаток в режиме действующего производственного процесса и выдача предупреждающих сигналов о появлении нежелательной геометрии лопаток. Такие предупреждающие сигналы позволят устранить аномалии в производственном процессе и выполнить экономию средств. Третий способ предполагает возможность корректировки управляющих программ оборудования с целью исключения производственных погрешностей на основе анализа серии лопаток.

В рамках рассматриваемой интеллектуальной системы обеспечения показателей качества можно выделить следующие модули:

1) накопление и хранение информации о геометрии и достигнутых ПКИ;

2) подготовка и анализ данных;

3) формирование базы данных онтологий;

4) интеллектуальный анализ данных и подготовка принятия производственных и конструкторских решений;

5) экспорт/импорт информации из системы управления данными об изделии PDM;

6) связь с системой диспетчирования производства;

7) производственная система контроля геометрии деталей и сборочных единиц ГТД;

8) система хранения показателей качества ГТД (стендовых и эксплуатационных);

9) комплектование, формирование электронного паспорта.

Схема рассмотренной системы представлена на рис. 1.

Математическое описание интеллектуальной системы обеспечения показателей качества авиационных двигателей

Для поставленных в работе задач необходимо выполнить разработку математической модели, обеспечивающей интеллектуальный анализ геометрии сложной формы. Также необходимо разработать требования к сохранению результатов, полученных с использованием модели интеллектуального анализа геометрии сложной формы.

Анализируя совокупность влияющих на процесс измерения факторов, можно выделить:

— погрешности, вносимые координатно-измерительной машиной (КИМ);

— факторы, обусловленные измеряемой деталью (видом и характером погрешности формы измеряемых поверхностей, деформациями от зажимных механизмов, качеством поверхностного слоя, доступностью измерительных наконечников для измерения);

— влияние внешних факторов (температуры, вибрации, влажности, засоренности);

— методика измерения;

— радиус измерительного наконечника контактных КИМ.

В данной работе исключены из рассмотрения погрешности, вносимые КИМ и методикой измерения.

В качестве основных параметров, характеризующих сложную геометрию лопаток компрессора, выступают:

1) отклонения расположения сложного профиля (поверхности) от номинально заданного положения;

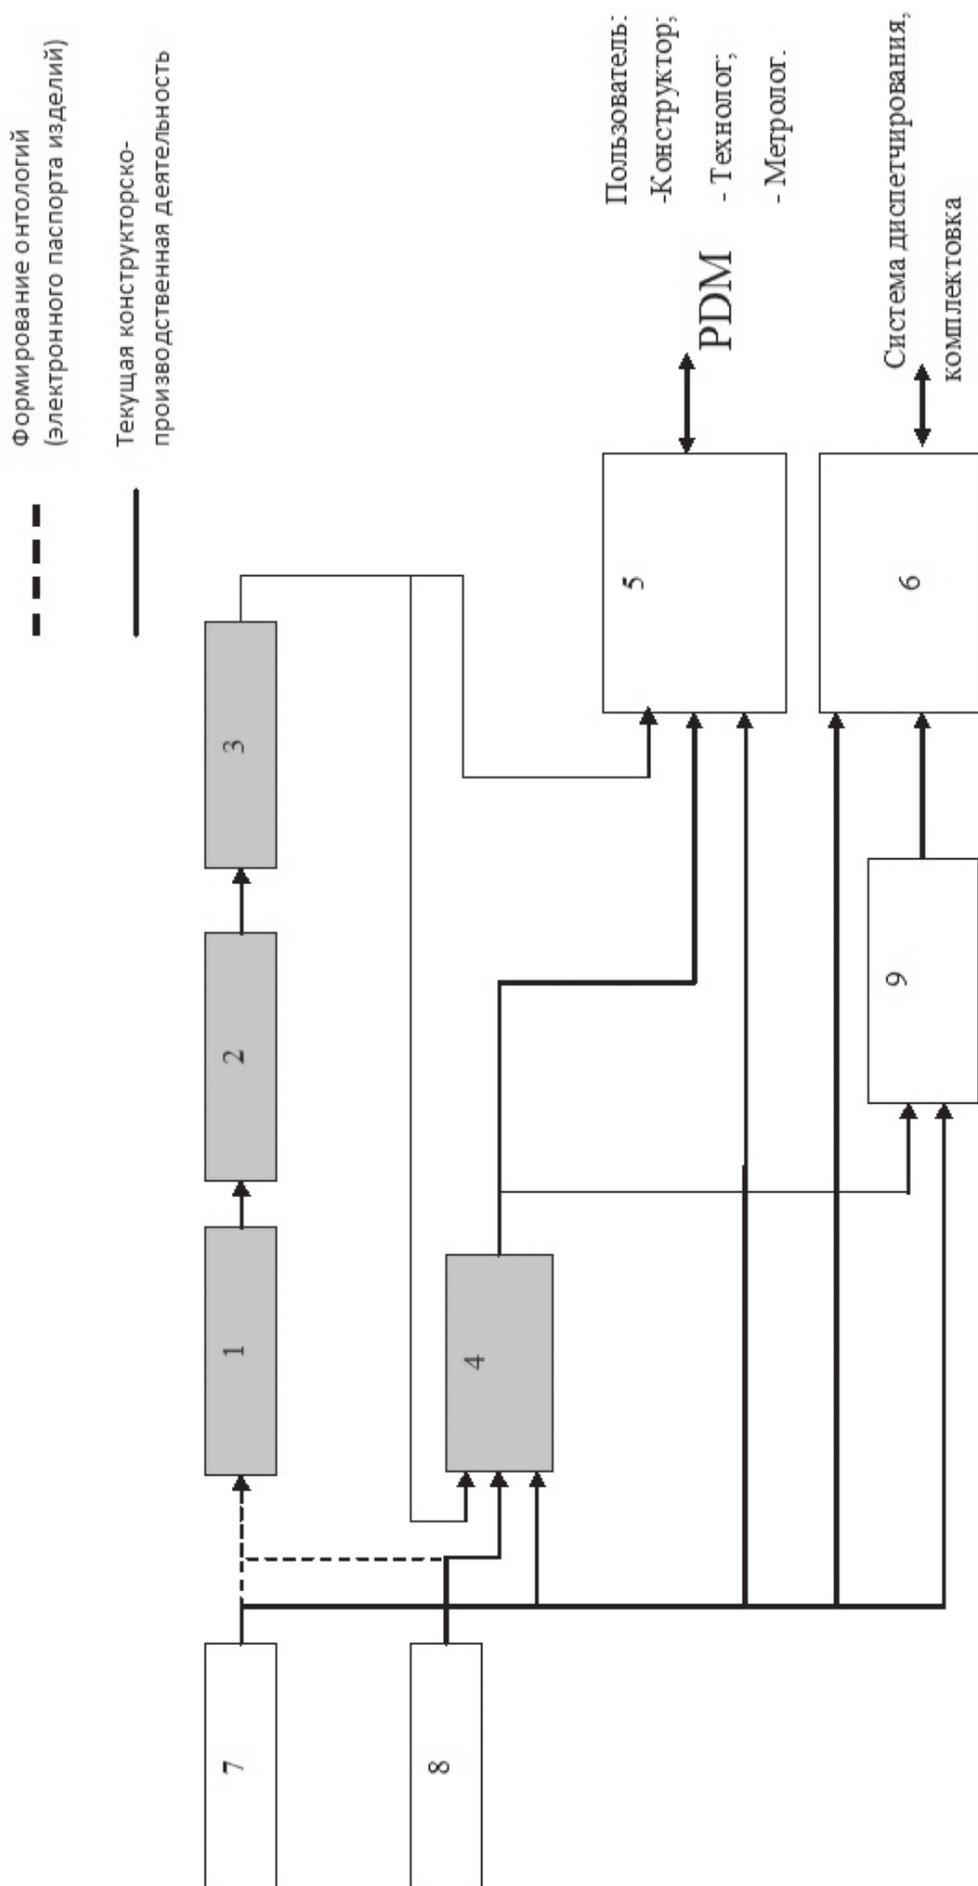


Рис. 1. Модульная блок-схема интеллектуальной системы обеспечения показателей качества изделий

2) отклонения формы сложного профиля (поверхности) от номинальной формы.

Для получения этих параметров возможно использовать следующие математические методы:

1) итеративный алгоритм ближайших точек, используемый в задачах метрологии при определении отклонения расположения деталей;

2) аппроксимация профиля и поверхности по задающим точкам для поиска отклонения формы детали;

3) получение гармонических характеристик отклонения формы с помощью преобразования Фурье.

Рассмотрим используемые в работе математические методы и разработанные на их основе модели для решения поставленных задач.

При контроле изготовления деталей, имеющих сложные поверхности (лопатки, штампы, пресс-формы), оценка их формы возможна методами косвенного сличения. Сравнение при измерении производится с CAD-моделью детали. Главным инструментом моделирования сложных поверхностей в CAD-системе является NURBS (неоднородный рациональный B-сплайн). В результате координатных измерений в систему измерительных машин загружается облако точек, которое сравнивается с характерными точками на CAD-модели. Причем оценку формы измеренной детали можно производить только после оценки отклонения расположения (совмещение системы координат измеренной детали с CAD-моделью).

В большинстве программных продуктов наилучшее совмещение для деталей, имеющих сложную форму поверхности, в программном обеспечении для КИМ осуществляется с использованием итеративного алгоритма ближайших точек (ICP, iterative closest point algorithm), основанного на методе наименьших квадратов [1].

В практике изготовления лопаток компрессора газотурбинных двигателей геометрия пера лопатки имеет решающее значение для характеристик работы двигателя. Чтобы точно оценить геометрические параметры, характеризующие форму лопаток, необходимо точное, адекватное совмещение измеренной детали с её CAD-моделью.

В наиболее общей формулировке алгоритм является итерационным алгоритмом, решающим проблему (задачу) оптимального вращения и перемещения для выравнивания облака точек к номинальным точкам на CAD-модели. Задача состоит в поиске минимума функции

$$f(R, T) = \frac{1}{n} \sum_{i=1}^n \|R \cdot p_i + T - q_i\|^2, \quad (1)$$

где n — количество точек, по которым производится совмещение;

p_i — координаты i -й измеренной точки;

R — матрица вращения координат точек измеренного профиля;

T — вектор транспонирования координат точек измеренного профиля;

q_i — координаты точки на CAD-модели.

Суть припасовки — найти T и R оцененного профиля относительно номинального и преобразовать координаты оцененного профиля, исключив погрешность расположения. Для поиска параметров R и T на каждой итерации алгоритма используются методы многомерной безусловной минимизации, производится уточнение ближайших точек на модели и измеренном профиле. Итерации продолжаются, пока измерения параметров T и R не станут меньше заданной величины.

Координаты точки реального профиля, совмещенного наилучшим образом с точками номинально профиля, находятся путем матричного произведения координат точек реального профиля матрицы преобразования:

$$P_{\text{пр}} = P \cdot M. \quad (2)$$

Здесь M — матрица трансформации положения, которая в двухмерной постановке имеет вид

$$M = \begin{bmatrix} \cos \alpha & \sin \alpha & 0 \\ -\sin \alpha & \cos \alpha & 0 \\ t_x & t_y & 1 \end{bmatrix}, \quad (3)$$

где α — угол поворота профиля; t_x, t_y — элементы транспонирования вдоль координатных осей матрицы T .

Существенным фактором, влияющим на точность работы алгоритма ICP, является кривизна измеренного профиля. Детали типа лопатки ГТД, пресс-формы, штампы, ряд корпусных деталей имеют существенную кривизну. Кривизна деталей влияет на точность измерения координат точек при измерении наконечником сферической формы. Чем выше кривизна измеряемой поверхности, тем больше возникающая при измерении погрешность вследствие отличия фактического от теоретического вектора нормали в точке контакта поверхности.

Отклонение формы рассчитывается как расстояние между точками номинального и «совмещенного наилучшим образом» профилей.

Возникает необходимость представления массива данных по отклонению формы в виде одного или

нескольких ключевых параметров, ее характеризующих. В работе в качестве характеризующих отклонение формы параметров рассчитывались ее периодические составляющие: амплитуда и частота. Отклонение формы представляет собой дискретные ряды данных в виде $h = f(t)$, где t — длина профиля.

В качестве инструмента анализа использовалось преобразование Фурье ($F(w)$). Отклонение формы $f(t)$ можно представить как

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F(w) \cdot e^{iwt} dt, \quad (4)$$

где

$$F(w) = \int_{-\infty}^{+\infty} f(t) \cdot e^{-iwt} dt. \quad (5)$$

$f(t)$ и $F(w)$ называются парой преобразования Фурье. Уравнение (4) показывает, что $f(t)$ представлено в виде семейства гармоник e^{-iwt} и коэффициентов $F(w)$, являющихся амплитудами гармоник в сигнале $f(t)$. $F(w)$ не зависит от времени, он представляет собой частотный состав случайного процесса, который предполагается стационарным, так что его статистические данные не меняются со временем. Используя полученный ряд Фурье, можно определить амплитуды $F(w)$ и соответствующие им длины волн w , отвечающих за различные виды погрешностей, имеющих периодический характер [2].

Можно смоделировать геометрию отклонения формы на различных участках профилей в виде

$$\Delta F(x) = \sum_1^m A_i \cos(k_i x / l_i \cdot 2\pi + \varphi_i), \quad (6)$$

где A_i, k_i — амплитуда и частота гармонической составляющей;

l_i — длина i -го участка функции;

φ_i — фаза i -й гармонической составляющей.

Таким образом, в результате анализа были получены характеризующие геометрию профилей лопаток компрессора ГТД параметры: амплитуды A и частоты k отклонения формы на различных участках профиля; величины смещения вдоль координатных осей t_x, t_y и угол разворота профиля α от номинального положения.

Точность геометрии профилей (поверхности) лопаток нормируется следующими показателями:

1) допуск на отклонение формы профиля относительно номинальной формы $\pm 0,04$ до $\pm 0,075$ мм;

2) смещение профиля от номинального расположения в направлении оси Y в одну сторону по всей длине пера; допуск задается на верхнее и нижнее сечения в пределах от 0,1 до 0,25 мм в зависимости от длины пера; в остальных сечениях допуск распределяется по линейной зависимости;

3) разворот профиля вокруг оси Z ; допуск задается на верхнее и нижнее сечения в пределах от ± 6 до $\pm 12'$; в остальных сечениях допуск распределяется по линейной зависимости.

Базовыми поверхностями лопаток компрессора являются поверхности хвостовика трапециевидной формы, называемой в некоторых литературных источниках «ласточкин хвост». Хвостовик трапециевидной формы включает в себя четыре плоских поверхности. Две плоские поверхности образуют угол, третья находится в основании рассматриваемого угла, четвертая перпендикулярна третьей, образует торец. Третья плоская поверхность используется для задания первой главной оси, по которой лопатка лишается трех степеней свободы: двух вращательных и одной поступательной. Две поверхности, образующие угол, используются для задания второй главной оси, по которой лопатка лишается двух степеней свободы: одной вращательной и одной поступательной. Четвертая плоская поверхность используется для задания оставшейся поступательной степени свободы.

Таким образом, геометрия профиля (поверхности) лопатки характеризуется комплексом геометрических параметров. Нахождение этих параметров в допустимых пределах, однако, не гарантирует одинаковые эксплуатационные характеристики авиадвигателей, в случае если они имеют различные значения для разных лопаток. Учет такого характера различий позволит осуществить предлагаемая модель анализа и классификации геометрии лопаток компрессора ГТД.

Для адекватного группирования параметров, имеющих разную природу (смещение и угол, отклонение формы и кривизна), было проведено нормирование входных параметров группировки в диапазон $[0, 1]$ по формуле

$$P_{\text{норм } i} = \frac{P_i - P_{\text{min}}}{P_{\text{max}} - P_{\text{min}}}, \quad (7)$$

где P — нормируемый параметр.

После проведения нормирования параметров геометрии профиля на результаты классификации не оказывала влияния разница в мерах их измерения.

Задачу автоматизированного распознавания можно сформулировать как задачу кластеризации.

Задача кластеризации (или обучения без учителя) заключается в следующем. Имеются обучающая выборка $X^m = \{x_1, \dots, x_m\} \subset X$ и функция расстояния между объектами $\rho(x_i, x_j)$. Требуется разбить выборку на непересекающиеся подмножества, называемые *кластерами*, так, чтобы каждый кластер состоял из объектов, близких по метрике ρ , а объекты разных кластеров существенно различались. При этом каждому объекту $x_j \in X^m$ приписывается метка (номер) кластера U_j .

Алгоритм кластеризации — это функция $a: X \rightarrow Y$, которая любому объекту $x \in X$ ставит в соответствие метку кластера $u \in Y$. Множество меток Y в некоторых случаях известно заранее, однако чаще ставится задача определить оптимальное число кластеров с точки зрения того или иного критерия качества кластеризации.

Решение задачи кластеризации принципиально не однозначно, и тому есть несколько причин. Во-первых, не существует однозначно наилучшего критерия качества кластеризации. Известен целый ряд достаточно разумных критериев, а также ряд алгоритмов, не имеющих чётко выраженного критерия, но осуществляющих достаточно разумную кластеризацию «по построению». Все они могут давать разные результаты. Во-вторых, число кластеров, как правило, не известно заранее и устанавливается в соответствии с некоторым субъективным критерием. В-третьих, результат кластеризации существенно зависит от метрики ρ , выбор которой, как правило, также субъективен и определяется экспертом.

В качестве моделей кластеризации в работе использовались: 1) метод k -средних, часто применяемый в практике создания различных баз данных по типовым деталям [3] и 2) самоорганизующиеся нейронные сети.

Метод k -средних — наиболее популярный метод кластеризации. Действие алгоритма таково, что он стремится минимизировать суммарное квадратичное отклонение точек кластеров от центров этих кластеров:

$$V = \sum_{i=1}^k \sum_{x_j \in S_i} (x_j - \mu_i)^2, \quad (8)$$

где k — число кластеров; S_i — полученные кластеры; $i = 1, 2, \dots$; k, μ_j — центры масс векторов $x_j \in S_i$.

Алгоритм k -средних разбивает множество элементов векторного пространства на заранее известное число кластеров k .

Основная идея заключается в том, что на каждой итерации перевычисляется центр масс для каждого кластера, полученного на предыдущем шаге, затем векторы разбиваются на кластеры вновь в соответствии с тем, какой из новых центров оказался ближе по выбранной метрике [4].

Алгоритм завершается, когда на какой-то итерации не происходит изменения центра масс кластеров. Это происходит за конечное число итераций, так как количество возможных разбиений конечного множества конечно, а на каждом шаге суммарное квадратичное отклонение V уменьшается, поэтому заикливание невозможно.

Задача анализа больших информационных массивов данных, как в случае классификации производственной статистики деталей ГТД, также может быть успешно решена с применением специального класса самоорганизующихся нейронных сетей [5, 6]. Эти сети основаны на конкурентном обучении. Отдельные нейроны входного слоя такой сети соревнуются за право активации, в результате чего активным оказывается один нейрон в сети (или в группе). Выходной нейрон, который выиграл данное соревнование, называется победившим. Одним из способов организации такой конкуренции между нейронами является использование отрицательных обратных связей между ними.

Свойство самоорганизации относится к наиболее привлекательным свойствам нейронных сетей. Этим свойством обладают самоорганизующиеся нейронные сети, описанные финским ученым Т. Кохоненом. Нейроны самоорганизующейся сети могут быть обучены выявлению групп векторов входа, обладающих некоторыми общими свойствами. Самоорганизующиеся нейронные сети с неупорядоченными нейронами называют слоями Кохонена.

Рассмотрим самоорганизующуюся нейронную сеть с единственным слоем, задача которой заключается в том, чтобы правильно сгруппировать (кластеризировать) поступающие в нее векторы входа. Архитектура слоя Кохонена представлена на рис. 2.

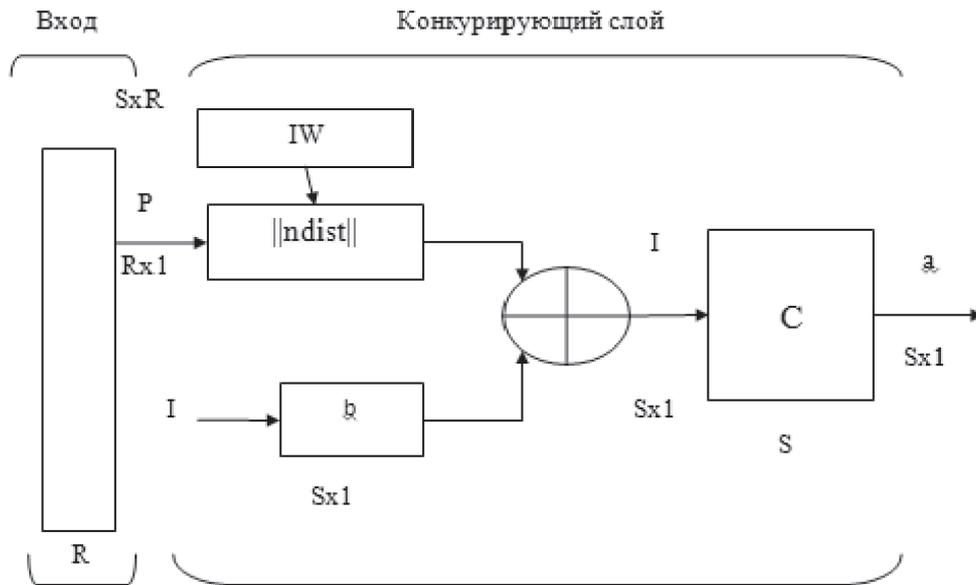


Рис. 2. Архитектура слоя Кохонена

В представленном на рис. 2 слое применена конкурирующая функция активации. В модели использован блок *ndist* для вычисления отрицательного евклидова расстояния между вектором входа *P* и строками матрицы весов *IW*. Вход функции активации *n* — это результат суммирования вычисленного расстояния с вектором смещения *b*. Если все смещения нулевые, максимальное значение *n* не может превышать 0. Нулевое значение *n* возможно только когда вектор входа *P* оказывается равным вектору веса одного из нейронов. Если смещения отличны от 0, то возможны и положительные значения для элементов вектора *n*.

Конкурирующая функция активации анализирует значения элементов вектора *n* и формирует выходы нейронов, равна 0 для всех нейронов, кроме одного — нейрона-победителя, имеющего на входе максимальное значение. Таким образом, вектор выхода слоя *a* имеет единственный элемент, равный 1, который соответствует нейрону-победителю; остальные равны 0. Такая активационная характеристика может быть описана следующим образом:

$$a_i = \begin{cases} 1, & i \neq i^*, \quad i^* = \arg(\max n_i); \\ 0, & i = i^*. \end{cases} \quad (9)$$

Эта активационная характеристика называется конкурирующей, она устанавливается не на отдельный нейрон, а на слой. Номер активного нейрона *i** определяет ту группу, к которой наиболее близок входной вектор.

Была разработана автоматизированная система идентификации законов распределения нейронной

сети Кохонена. В качестве меры соответствия весов нейрона-победителя входному вектору была выбрана евклидова мера, вычисляемая по формуле

$$d(p, i IW) = \|p - IW\| = \sqrt{\sum_{j=1}^N (p_j - i IW_j)^2}, \quad (10)$$

где *p*, *IW* — веса входного вектора и нейрона сети соответственно [7].

Результаты работы

В рамках разработанной системы с использованием рассмотренных выше моделей осуществлена кластеризация серии профилей корытца лопаток компрессора ГТД, полученных в результате измерения на координатно-измерительной машине DEA Global Performance 07.10.07. Рассчитаны отклонения расположения и формы профилей. Для описания формы на имитируемых профилях для полученных отклонений формы было выполнено оконное преобразование Фурье и получены характеристики гармонических составляющих отклонения формы для четырех участков профиля. Программы для обработки данных были созданы в пакете MATLAB [8]. На рис. 3 показаны графики отклонения формы в сечениях пера лопаток.

На рисунке рассматривается серия лопаток, изготовленных по одному технологическому процессу с одной настройкой. Анализируя отдельные реализации профиля, можно отметить, что профиль пера лопатки имеет повторяемость формы. Так, для серии характерны значительные отклонения на входной и выходной кромках, что обусловлено высокой кривизной их поверхности.

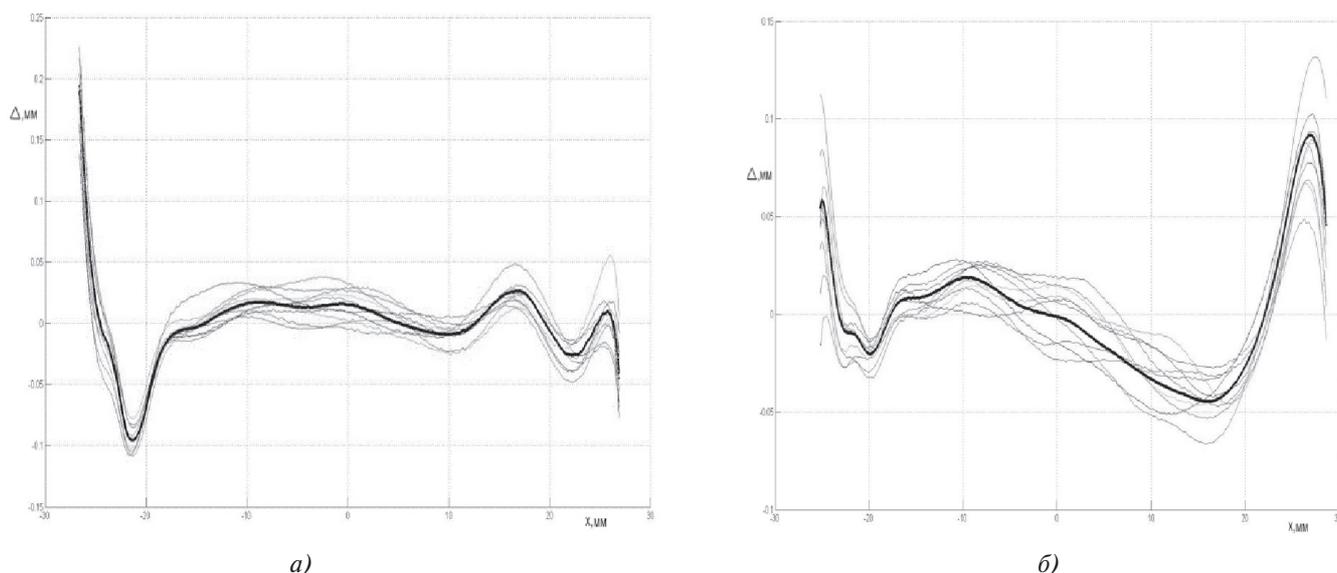


Рис. 3. Отклонение формы для сечения корытца на высоте: а — 17 мм; б — 172 мм

Полученные характеристики были кластеризованы с помощью алгоритма *k*-means и нейронных сетей на четыре группы. Полученные центроиды (типичные представители) каждой из групп представлены в табл. 1.

Для проверки точности моделей кластеризации центроиды табл. 1 использовались для моделирования искусственных профилей. Величина параметров изменялась случайным образом в пределах варьирования параметров производственной статистики.

В табл. 2 представлены моделируемые максимальные и минимальные значения параметров в классах для 200 моделируемых профилей лопаток.

Ввиду того, что частоты гармонических составляющих погрешностей формы на соответствующих участках у всех профилей одинаковы, эти параметры не использовались в качестве параметров для кластеризации.

На рис. 4 и 5 представлены облака значений, отнесенных к четырем классам параметров откло-

Таблица 1

Центры кластеров измеренных лопаток компрессора ГТД

Параметры профиля	A1, мм	A2, мм	A3, мм	A4, мм	k1	k2	k3	k4	t_x , мм	t_y , мм	α , рад
1 группа	0,0351	0,0062	0,0066	0,0122	3	4	4	4	0,0296	-0,1271	-0,0011
2 группа	0,0247	0,0022	0,0080	0,0109	3	4	4	4	0,0032	-0,0198	-0,0006
3 группа	0,0297	0,0037	0,0101	0,0127	3	4	4	4	-0,0132	0,0509	-0,0014
4 группа	0,0303	0,0033	0,0055	0,0124	3	4	4	4	-0,0324	0,1266	-0,0009

Таблица 2

Размах варьирования параметров в группах модельных профилей

Параметры профиля	A1, max/min, мм	A2, max/min, мм	A3, max/min, мм	A4, max/min, мм	x, max/min, мм	y, max/min, мм	α , max/min, рад
1 группа	0,0522/0,0182	0,009/0,0032	0,0097/0,0034	0,0182/0,0063	0,0514/0,0083	(-0,0337)/-0,2146	(-0,0004)/-0,0019
2 группа	0,038/0,0124	0,0033/0,0011	0,0122/0,0038	0,0165/0,0051	0,0054/0,0009	(-0,0053)/-0,0335	(-0,0002)/-0,0010
3 группа	0,046/0,0165	0,0057/0,0017	0,0016/0,0005	0,0196/0,0059	(-0,0038)/-0,0229	0,0883/0,0131	(-0,0005)/-0,0024
4 группа	0,0438/0,0168	0,0048/0,0020	0,0080/0,0031	0,0177/0,0075	(-0,0083)/-0,0556	0,2154/0,0336	(-0,0002)/-0,0016

нений расположения и формы. Также были вычислены центры кластеров, характеризующие типовых представителей каждого класса.

В табл. 3 показана относительная точность кластеризации в случаях работы алгоритма *k*-средних и нейронной сети в виде доли неправильно кластеризованных деталей в общем количестве деталей групп.

Результаты кластеризации массива модельных профилей представлены на рис. 6.

Полученные параметры для типовых представителей использовались для вычисления координат точек типовых представителей каждого класса от CAD-моделей.

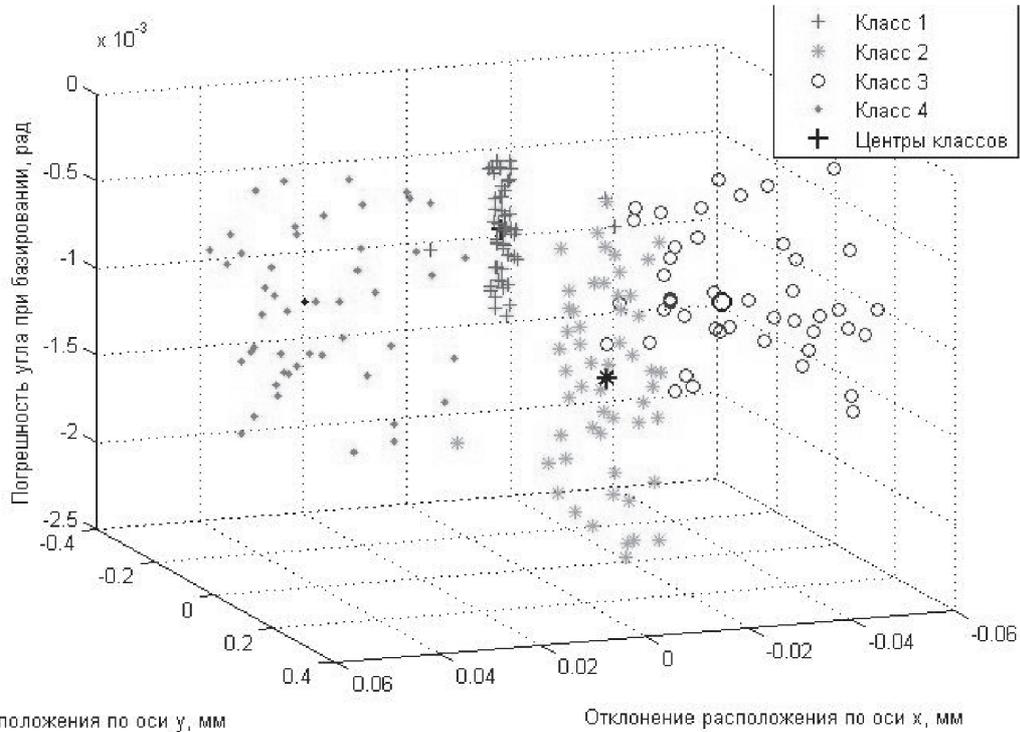


Рис. 4. Кластеризация 200 профилей на четыре группы в координатах параметров отклонения расположения

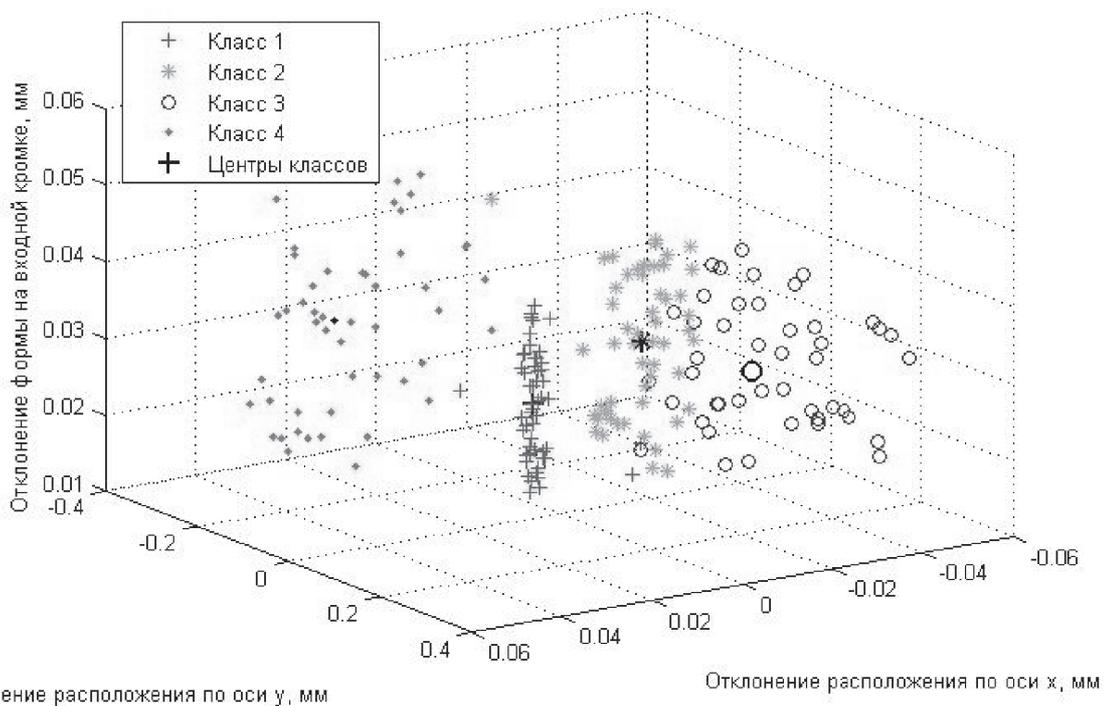


Рис. 5. Кластеризация 200 профилей на четыре группы в координатах параметров отклонения формы

Таблица 3 имущество перед статистическими методами ввиду возможности обучения и кластеризации новых объектов на основе накопленного опыта.

Доли неправильно кластеризованных элементов в группах

Методы	Относительная погрешность кластеризации, %			
	1 группа	2 группа	3 группа	4 группа
к-среднее	6	0	0	22
Нейронная сеть	8	0	2	10

Модель интеллектуального анализа геометрии сложной формы была реализована в пакете MATLAB®. Разработанная модель прошла апробацию на производственной статистике, представленной на серии лопаток компрессора ГТД. Для дальнейшей реализации модели в производстве необходима разработка программных модулей.

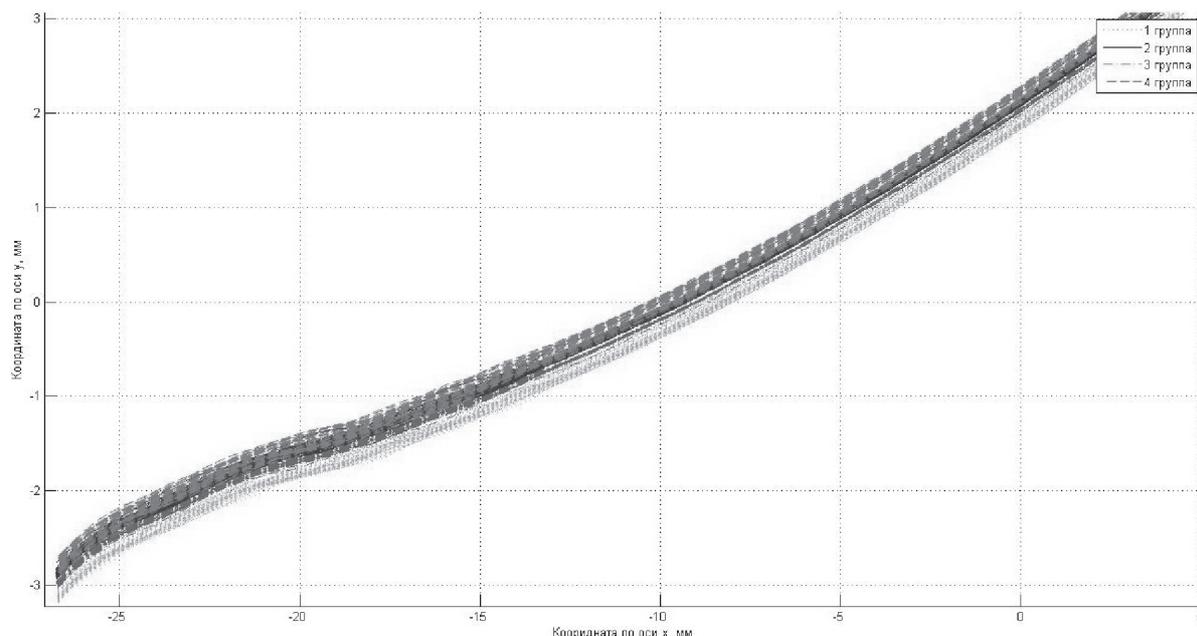


Рис. 6. Реализации профилей лопаток компрессора ГТД

Выводы

Рассмотрена совокупность методик и реализующих алгоритмов для создания модулей формирования базы данных онтологий и интеллектуального анализа данных интеллектуальной системы обеспечения показателей качества деталей авиационного двигателя.

Большое внимание уделено разработке модели анализа и классификации данных представленных координатами точек сложных профилей. Рассмотрено несколько подходов к кластеризации производственной статистики. На первом этапе ставилась задача выявления признаков, по которым возможно проводить классификацию деталей, поверхностей и сечений. В качестве таких параметров были выбраны геометрические особенности (отклонение формы и расположения).

На втором этапе проводилась кластеризация статистическим методом к-средних и с использованием сетей Кохонена. Использование нейронных сетей для решения задач кластеризации имеет пре-

Библиографический список

1. *Besl P.J., McKay N.D.* A method for registration of 3-D shapes//IEEE Transactions on Pattern Analysis and Machine Intelligence. 1992, vol. 14, № 2, pp. 239-256.
2. *Залманзон Л.А.* Преобразования Фурье, Уолша, Хаара и их применение в управлении, связи и других областях. — М.: Наука, 1989. — 496 с.
3. *Jayanti S., Kalyanaraman Y., Ramani K.* Shape-based clustering for 3D CAD objects: A comparative study of effectiveness// Computer-Aided Design. 2009, №41, pp. 999-1007.
4. *Demuth H., Beale M.* Neural Network Toolbox For Use with MATLAB // Neural Network Toolbox User’s Guide. 2003. — 840 p.
5. *Niu Y., Wong Y., Hong G.* Intelligent sensor system approach for reliable toolflank wear recognition// International Journal of Advanced Manufacturing Technology. 1998, №14 (2),pp. 77-84.
6. *Emel E.* Tool wear detection by neural network based acoustic emission sensing, American Society of Mechanical Engineers// Dynamic Systems and Control Division (Publication) DSC. 1991, №28, pp.79-85.
7. *Осовский С.* Нейронные сети для обработки информации. — М.: Финансы и статистика, 2002. — 344 с.

8. Кетков Ю.Л., Кетков А.Ю., Штульц М.М. *MATLAB 7: программирование, численные методы.* — СПб.: БХИ-Петербург, 2005. — 752 с.

ANALYSIS MODEL AND CLASSIFICATION OF THE GEOMETRY OF GAS TURBINE ENGINE BLADES

Pechenin V.A.* , Bolotov M.A.**

Samara State Aerospace University named after academician S.P. Korolev (National Research University), SSAU, 34, Moscovskoe shosse, Samara, 443086, Russia

* e-mail: vadim.pechenin2011@yandex.ru

** e-mail: maikl.bol@gmail.com

Abstract

The quality of aircraft engines (specific consumption, gas-dynamic stability, reliability, service life) is embedded in the course of the design process, fixed out at the stage of finalization, provided in the course of production, and implemented during operation. Account for actual geometry of the parts during design process, and forming the best for current manufacturing environment conditions geometry of the products during manufacturing and assembling is one of the reserves allowing aircraft engine quality increase. Realization of the above mentioned reserve becomes possible with implementation of intellectual system of aircraft engines quality provision. The article presents the technique for the intellectual system of aircraft engines quality provision forming. It shows the structure of the intellectual system of aircraft engines quality provision. Mathematical model of the system with regard to analysis and clustering of complex shapes and surfaces is built. The analysis allows calculating parameters of a part location deviation from nominal geometry, and calculation deviation of parts shapes. Analysis tools are as follows: an iterative algorithm of nearest points, piecewise splines approximation of surface points, Fourier transform. We used an algorithm of k-means and self-organizing Kohonen's neural networks as clustering methods. For adequate profile parameters clustering (shape and position) these parameters were normalized to the range of [0,1]. Complex shape geometry intellectual analysis model was implemented in MATLAB(r). Within the framework of the developed system using obtained models, clustering of series of GTE bucket compressor blades, obtained as a result of measuring with CMMs DEA Global Performance 07.10.07. Implementation of neural networks seems to be more promising for the tasks of clustering solving compared to static methods, due to

the possibility of learning and clustering of new objects on the basis of accumulated know-how. For further model realization in manufacturing building of new program modules is necessary.

Keywords: analysis, Fourier transform, clustering, neural network.

References

1. Besl P.J., McKay N.D. A method for registration of 3-D shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1992, vol. 14, no. 2, pp. 239-256.
2. Zalmanzon L.A. *Preobrazovaniya Fur'e, Uolsha, Khaara i ikh primeneniye v upravlenii, svyazi i drugikh oblastiakh* (Fourier, Walsh, Haar transform and their application in management, communication and other areas), Moscow, Nauka, 1989, 496 p.
3. Jayanti S., Kalyanaraman Y., Ramani K. Shape-based clustering for 3D CAD objects: A comparative study of effectiveness. *Computer-Aided Design*, 2009, no. 41, pp. 999-1007.
4. Demuth H., Beale M. *Neural Network Toolbox For Use with MATLAB. Neural Network Toolbox User's Guide*, 2003, 840 p.
5. Niu Y., Wong Y., Hong G. Intelligent sensor system approach for reliable tool flank wear recognition. *International Journal of Advanced Manufacturing Technology*, 1998, no. 14(2), pp. 77-84.
6. Emel E. Tool wear detection by neural network based acoustic emission sensing, American Society of Mechanical Engineers. *Dynamic Systems and Control Division (Publication) DSC*, 1991, no. 28, pp.79-85.
7. Osovskii S. *Neironnye seti dlya obrabotki informatsii* (Neural network for information processing), Moscow, Finansy i statistika, 2002, 344 p.
8. Ketkov Yu.L., Ketkov A.Yu., Shtul'ts M.M. *MATLAB 7: programmirovaniye, chislennyye metody* (MATLAB 7: programming, numerical methods), St. Petersburg, BKhI-Peterburg, 2005, 752 p.